



Universidad
Carlos III de Madrid

Escuela Politécnica Superior

Departamento de Ingeniería Mecánica

GRADO EN INGENIERÍA EN TECNOLOGÍAS INDUSTRIALES

TRABAJO FIN DE GRADO

**ESTUDIO DEL FACTOR DE INTENSIDAD DE
TENSIONES EN UN EJE GIRATORIO
MEDIANTE LA APLICACIÓN DE REDES
NEURONALES**

Autor: Jaime López Béjar

Tutora: Patricia Rubio Herrero

Leganés, Junio de 2015

Agradecimientos

En primer lugar quiero agradecer a mi tutora, Patricia Rubio y a la profesora M^a Belén Muñoz Abella, haberme ofrecido la oportunidad de realizar este trabajo y haberme ayudado en todo lo que he necesitado a lo largo del trabajo.

También quiero agradecer a mis padres, Juan Antonio y Sagrario, su esfuerzo y su apoyo incondicional. Sin ellos nunca lo habría conseguido.

A mi hermano, Guillermo, por ser un referente para mí y por apoyarme en todo lo que me propongo.

A mis amigos Fernando, Joni, Pablo, Zapa, Almu, Paula, Raquel, Silvia y Susana, por su amistad a lo largo de todos estos años.

A todos los compañeros de clase que he tenido a lo largo de estos años, en especial a Carlos, Guille, Melgo, Meza, Quique y Yeray, que empezaron siendo compañeros de clase y hemos acabado siendo amigos. Que nuestra amistad dure muchos años.

Resumen

En este proyecto se pretende determinar el Factor de Intensidad de Tensiones adimensional en el frente de una fisura contenida en un eje a lo largo de un giro completo mediante la aplicación de Redes Neuronales Artificiales (RNA).

Para ello se resolverá el problema directo, a partir de los parámetros geométricos característicos de una fisura: profundidad relativa de fisura, factor de forma de fisura y posición relativa del frente de fisura, y la posición angular de la fisura se estimará el valor del Factor de Intensidad de Tensiones adimensional.

Palabras clave: Eje rotatorio, Redes Neuronales Artificiales.

Abstract

The objective of this project was to determinate the Stress Intensity Factor dimensionless along the crack front in a rotating shaft using Artificial Neural Networks.

For that, it will be resolved the direct problem, from different values of characteristics parameters and angular position will be estimated the values of Stress Intensity Factor dimensionless.

Keywords: Rotary shaft, Artificial Neuronal Networks.

Índice general

Capítulo 1	Introducción y objetivos.....	1
1.1	Introducción.....	1
1.2	Objetivos.....	3
1.3	Estructura del documento	4
Capítulo 2	Mecánica de Fractura	5
2.1	Introducción a la Mecánica de Fractura.....	5
2.2	Comportamiento de ejes fisurados.....	7
2.3	Geometría del frente de fisura	9
2.4	Comportamiento de la fisura en ejes giratorios	10
Capítulo 3	Redes Neuronales Artificiales (RNA).....	13
3.1	Introducción a las Redes Neuronales Artificiales (RNA).....	13
3.1.1	Etapas de una RNA	15
3.2	Redes perceptron multicapa.....	16
3.2.1	Algoritmo de retropropagación.....	19
3.3	Redes Neuronales de base radial	22
Capítulo 4	Metodología	25
4.1	Planteamiento del problema	25
4.2	Programación de la Red Neuronal Artificial	28

Capítulo 5 Resultados y discusión.....	33
5.1 Resultados.....	33
5.2 Discusión de los resultados.....	41
Capítulo 6 Conclusiones y trabajos futuros	42
6.1 Conclusiones.....	42
6.2 Trabajo futuros.....	43
Capítulo 7 Presupuesto	44
7.1 Planificación	44
7.2 Presupuesto	47
Bibliografía.....	50

Índice de figuras

Figura 2.1: Modos de fractura: (a) Modo I o de apertura, (b) Modo II o de cortadura, (c) Modo III o de cizalladura [1]	6
Figura 2.2: Eje fisurado sometido a tracción y flexión	7
Figura 2.3: Sección transversal de la zona fisurada y parámetros característicos de una fisura elíptica	10
Figura 2.4: Función de apertura y cierre del modelo de fisura abierta	11
Figura 2.5: Esquema de las situaciones de fisura completamente cerrada y completamente abierta [1]	11
Figura 2.6: Función de apertura y cierre propuesta por Mayes y Davies	12
Figura 3.1: Partes de una neurona de un cerebro [4]	14
Figura 3.2: Propagación y ponderación de señales en una red neuronal	14
Figura 3.3: Esquema aprendizaje supervisado	15
Figura 3.4: Esquema aprendizaje no supervisado	16
Figura 3.5: Arquitectura de una RNA percetron multicapa	17
Figura 3.6: Función sigmoidea o logística	18
Figura 3.7: Función tangente hiperbólica	18
Figura 3.8: Función escalón	18
Figura 3.9: Esquema de funcionamiento del algoritmo de retropropagación	19
Figura 3.10: Arquitectura de una red de base radial	22
Figura 3.11: Función gaussiana	24
Figura 4.1: Esquema del eje fisurado [1]	26
Figura 4.2: Variación de la profundidad relativa y del factor de forma de la fisura [1].	26
Figura 4.3: Posiciones en el frente de la fisura [1]	27
Figura 4.4: Ejemplo de gráfica de representación de datos reales y estimados por la red para el entrenamiento.....	29
Figura 4.5: Representación de la evolución del MSE	30
Figura 4.6: Ejemplo de recta de regresión lineal proporcionada por Matlab	31
Figura 4.7: Ejemplo de gráfica de representación de datos reales y estimados por la red para la generalización	32
Figura 5.1: Gráfica obtenida durante la etapa de aprendizaje	34
Figura 5.2: Recta de regresión lineal obtenida para el entrenamiento.....	35

Figura 5.3: Recta de regresión lineal obtenida para la validación.....	35
Figura 5.4: Comparación de los valores del FIT adimensional estimado por la red neuronal frente a los valores introducidos en la red neuronal para $\beta = 0$ y $\alpha = 0.1$	36
Figura 5.5: Comparación de los valores del FIT adimensional estimado por la red neuronal frente a los valores introducidos en la red neuronal para $\beta = 0$ y $\alpha = 0.3$	37
Figura 5.6: Comparación de los valores del FIT adimensional estimado por la red neuronal frente a los valores introducidos en la red neuronal para $\beta = 0$ y $\alpha = 0.5$	37
Figura 5.7: Comparación de los valores del FIT adimensional estimado por la red neuronal frente a los valores introducidos en la red neuronal para $\beta = 0.5$ y $\alpha = 0.1$	38
Figura 5.8: Comparación de los valores del FIT adimensional estimado por la red neuronal frente a los valores introducidos en la red neuronal para $\beta = 0.5$ y $\alpha = 0.3$	38
Figura 5.9: Comparación de los valores del FIT adimensional estimado por la red neuronal frente a los valores introducidos en la red neuronal para $\beta = 0.5$ y $\alpha = 0.5$	39
Figura 5.10: Comparación de los valores del FIT adimensional estimado por la red neuronal frente a los valores introducidos en la red neuronal para $\beta = 1$ y $\alpha = 0.1$	39
Figura 5.11: Comparación de los valores del FIT adimensional estimado por la red neuronal frente a los valores introducidos en la red neuronal para $\beta = 1$ y $\alpha = 0.3$	40
Figura 5.12: Comparación de los valores del FIT adimensional estimado por la red neuronal frente a los valores introducidos en la red neuronal para $\beta = 1$ y $\alpha = 0.5$	40
Figura 6.1: Diagrama de Gantt	46

Índice de tablas

Tabla 1: Costes de personal	47
Tabla 2: Costes de equipos	47
Tabla 3: Costes de licencias software.....	48
Tabla 4: Costes totales.....	49

Capítulo 1

Introducción y objetivos

1.1 Introducción

Es frecuente que los fallos producidos en máquinas rotativas, se produzcan debido a la aparición de fisuras en sus componentes. Estas fisuras, afectan tanto a la seguridad como al correcto funcionamiento de las máquinas, ya que pueden conducir a su rotura catastrófica. Los ejes, componentes importantes en este tipo de máquinas, están sometidos a una serie de esfuerzos, que pueden provocar la propagación de estas fisuras debido a la fatiga.

Las fisuras, generan un aumento de la flexibilidad local en un elemento mecánico, lo que produce cambios en su comportamiento estático y dinámico, que puede traducirse en un aumento en el incremento de los desplazamientos y la disminución de las frecuencias de vibración, entre otros.

En el caso de ejes rotatorios, también habrá que tener en cuenta el estado de apertura o cierre de la fisura, debido al movimiento rotatorio que sufre el eje. Para ello, se han desarrollado distintos modelos matemáticos para el estudio de este mecanismo de apertura y cierre. El modelo más simple considera que la fisura siempre está completamente abierta o completamente cerrada y se denomina *switching crack*. Otro modelo, denominado *breathing crack*, considera que la fisura se abre y se cierra gradualmente, pasando por estados intermedios.

El Factor de Intensidad de Tensiones (FIT) es un parámetro que caracteriza el estado tensional en el frente de una fisura. Para un eje giratorio, el valor del FIT variará en función de la posición angular en la que se encuentre la fisura, debido a la apertura/cierre de la fisura. Este valor será positivo cuando la fisura se encuentre abierta y sufra esfuerzos de tracción y tendrá un valor de cero cuando se encuentre cerrada.

Para afrontar este tipo de problemas, se puede emplear el método directo, en el que a partir de parámetros geométricos de la fisura se obtiene el valor del FIT adimensional, y el método inverso en que a partir del valor del FIT adimensional o de los desplazamientos que sufre el eje se obtienen los parámetros característicos de la fisura.

Una forma de abordar este problema, es mediante el uso de Redes Neuronales Artificiales (RNA). Las RNA son estructuras matemáticas capaces de estimar relaciones no lineales complejas entre unas variables de entrada y unas variables de salida, de manera que se puedan predecir valores de salida ante nuevos valores de entrada.

1.2 Objetivos

El objetivo de este trabajo, es determinar el FIT en un giro completo del eje, empleando Redes Neuronales Artificiales. Para ello, se utilizarán como variables de entrada los parámetros característicos del frente de la fisura y la posición angular de la fisura y como variable de salida se obtendrá el FIT. Estas variables son:

- Variables de entrada:
 - Profundidad relativa de la fisura
 - Factor de forma de la fisura
 - Posición relativa en el frente de fisura
 - Posición angular de la fisura

- Variables de salida:
 - Factor de Intensidad de Tensiones adimensional

Para ello, se realizarán diferentes tipos de redes neuronales para resolver el problema mediante el método directo.

1.3 Estructura del documento

El Trabajo Fin de Grado está distribuido en 7 capítulos, el primero de ellos destinado a esta introducción.

En el capítulo 2 se resumen algunos de los conceptos fundamentales de la mecánica de fractura, explicando el comportamiento de ejes con fisuras, los parámetros característicos de una fisura y el Factor de Intensidad de Tensiones.

En el capítulo 3 se explica el funcionamiento de las redes neuronales artificiales (RNA) y sus características.

En el capítulo 4 se describe el problema a resolver y la metodología seguida para realizar la red neuronal artificial.

En el capítulo 5 se muestran los resultados obtenidos mediante la aplicación de la red neuronal y posteriormente se encuentra una discusión de estos resultados.

En el capítulo 6 se exponen las conclusiones y los posibles futuros trabajos.

En el capítulo 7 se proporciona un presupuesto, analizando los costes económicos que conllevan la realización de este trabajo.

Por último se presenta la bibliografía empleada para la realización de este Trabajo Fin de Grado.

Capítulo 2

Mecánica de Fractura

2.1 Introducción a la Mecánica de Fractura

La mecánica de fractura se encarga de analizar el comportamiento de elementos mecánicos, considerando la existencia de defectos, para determinar cuando puede producirse una fractura frágil en el material. Esta disciplina nació a principios del siglo XX, evolucionando desde la teoría hasta la práctica, siendo de gran importancia en la actualidad para el estudio de rotura catastrófica en todo tipo de estructuras, desde partes de máquinas como ejes hasta estructuras como aviones o puentes.

Una fisura puede estar expuesta a tres modos de fractura diferentes, en función de la dirección de aplicación de la carga con respecto al plano que contiene la fisura (ver Figura 2.1). En el modo I (apertura), las tensiones y los desplazamientos de los labios de la fisura, son normales respecto al plano que contiene a la fisura. En el modo II (cortadura), las tensiones y los desplazamientos se encuentran contenidos en el plano y la dirección de propagación de la fisura es la misma que la dirección de la tensión. En el modo III (cizalladura), la tensión y los desplazamientos se encuentran contenidos en el plano de la fisura y la dirección de propagación de la fisura es perpendicular a la dirección de la tensión.




Figura 2.1: Modos de fractura: (a) Modo I o de apertura, (b) Modo II o de cortadura, (c) Modo III o de cizalladura [1]

Estos modos de fractura pueden aparecer de manera independiente (modos puros) o varios a la vez (modos mixtos). Para la resolución de los modos mixtos, se empleará el método de superposición. El modo I es el más frecuente e importante.

El FIT es un parámetro que define la magnitud de las tensiones locales en el entorno del fondo de una fisura y se suele expresar como [1]:

$$K_I = F_I \cdot \sigma \cdot \sqrt{\pi \cdot a} \quad (2.1)$$

donde F_I es el factor de corrección adimensional que depende de la geometría de la fisura, también denominado FIT adimensional, σ es la tensión de referencia dependiente de la sollicitación externa, a es la profundidad de la fisura y K_I el FIT en modo I.

Si el valor del FIT supera un valor crítico, denominado tenacidad de fractura K_{IC} , que es una propiedad del material, se producirá una propagación de la fisura.

De forma que el criterio local de fractura en modo I quedará determinado de la siguiente forma:

$$K_I \geq K_{IC} \quad (2.2)$$

2.2 Comportamiento de ejes fisurados

La presencia de fisuras en un elemento mecánico produce cambios en su comportamiento estático y dinámico, debido al aumento de la flexibilidad local del elemento. Esto provoca un aumento de los desplazamientos, una disminución de las frecuencias de vibración y la modificación de las órbitas que describen sus secciones, entre otras cosas.




Figura 2.2: Eje fisurado sometido a tracción y flexión

La aparición de fisuras en un elemento expuesto a un esfuerzo de tracción N y a un momento flector M (Figura 2.2), se pueden modelizar admitiendo discontinuidades en los desplazamientos verticales (Δu) y en los giros ($\Delta \theta$), en la sección fisurada, relacionados con los esfuerzos mediante:

$$\Delta u = \lambda_{nn}N + \lambda_{nm}M \quad (2.3)$$

$$\Delta \theta = \lambda_{mm}M + \lambda_{mn}N \quad (2.4)$$

donde λ_{ij} son los coeficientes de flexibilidad y

$$\Delta u = u_2 - u_1 \quad (2.5)$$

$$\Delta \theta = \theta_2 - \theta_1 \quad (2.6)$$

siendo u_1 y θ_1 el desplazamiento y el giro en la sección que se encuentra a la izquierda de la fisura y u_2 y θ_2 el desplazamiento y el giro en la sección situada a la derecha de la fisura.

Para la obtención de estos coeficientes de flexibilidad, se pueden emplear las ecuaciones que relacionan la tasa de liberación de energía G , con el factor de intensidad de tensiones, K_I , que en condiciones de deformación plana será:

$$G_N = \frac{1-\nu^2}{E} K_{I,N}^2 = \frac{N^2}{2} \frac{d\lambda_{nn}}{dA} \quad (2.7)$$

$$G_M = \frac{1-\nu^2}{E} K_{I,M}^2 = \frac{N^2}{2} \frac{d\lambda_{mm}}{dA} \quad (2.8)$$

donde E es el módulo de Young del material, ν el coeficiente de Poisson del material y dA es el diferencial de área de la fisura.

Si se integran las ecuaciones anteriores, se obtienen los coeficientes de flexibilidad para esfuerzos de tracción, flexión y para la combinación de ambas:

$$\lambda_{nn} = \frac{2(1-\nu^2)}{E} \int_A \left(\frac{K_{I,N}}{N} \right)^2 dA \quad (2.9)$$

$$\lambda_{mm} = \frac{2(1-\nu^2)}{E} \int_A \left(\frac{K_{I,M}}{M} \right)^2 dA \quad (2.10)$$

$$\lambda_{mn} = \frac{2(1-\nu^2)}{E} \int_A \left(\frac{K_{I,N}}{N} \right) \left(\frac{K_{I,M}}{M} \right) dA \quad (2.11)$$

La obtención de estos coeficientes, están desarrollados en el artículo de L. Rubio y B. Muñoz [2], mediante ajustes polinómicos del factor de intensidad de tensiones, para un eje con una fisura elíptica.

2.3 Geometría del frente de fisura

Diversos autores, han abordado el problema del comportamiento de los ejes fisurados considerando un frente de fisura recto. Esta hipótesis es correcta y los resultados obtenidos son válidos, pero en el mundo real se observa que la mayoría de las fisuras en ejes rotatorios presentan un frente de fisura elíptico.

Los parámetros geométricos característicos de una fisura (ver figura 2.3) con frente elíptico son[1]:

- $\alpha = \frac{a}{D} \rightarrow$ Profundidad relativa de la fisura
- $\beta = \frac{a}{b} \rightarrow$ Factor de forma de la fisura
 - $\beta = 0 \rightarrow$ Fisura de frente recto
 - $0 < \beta < 1 \rightarrow$ Fisura de frente elíptico
 - $\beta = 1 \rightarrow$ Fisura de frente semicircular
- $\gamma = \frac{w}{h} \rightarrow$ Posición relativa en el frente de fisura




Figura 2.3: Sección transversal de la zona fisurada y parámetros característicos de una fisura elíptica

2.4 Comportamiento de la fisura en ejes giratorios

Debido al movimiento rotatorio que sufre el eje, habrá que tener en cuenta los esfuerzos, de tracción o de compresión, a los que está sometido la fisura. De esta manera, en función de la posición angular de la fisura, el estado de apertura de la fisura variará a lo largo del giro del eje. Cuando el eje alcance la rigidez máxima, la fisura se encontrará totalmente cerrada y se comportará como un eje que no sufriera ningún daño. Por otro lado, la fisura estará completamente abierta cuando la rigidez del eje sea mínima.

Los modelos más utilizados para definir la función de apertura y cierre son [1]:

- **Modelos de fisura abierta:** la fisura se encuentra abierta a lo largo de todo el giro. De forma que la función de apertura y cierre queda expresada en la ecuación 2.12 y su respectiva gráfica en la figura 2.4.

$$g(\theta) = 1 \quad (2.12)$$




Figura 2.4: Función de apertura y cierre del modelo de fisura abierta

- **Modelos de fisura abierta o cerrada (*switching crack*):** en estos modelos la fisura está completamente cerrada o completamente abierta, sin tener en cuenta los cierres y aperturas parciales de la fisura (ver figura 2.5).




Figura 2.5: Esquema de las situaciones de fisura completamente cerrada y completamente abierta [1]

- **Modelos de apertura y cierre gradual de la fisura (*breathing crack*):** en estos modelos la apertura de la fisura cambia continuamente con la rotación del eje, considerándose estados de apertura y cierre parciales de la fisura. Mayes y Davies[8] propusieron la función de apertura y cierre mostrada en la expresión 2.13, que se corresponde con la gráfica mostrada en la figura 2.6.

$$g(\theta) = \frac{1+\cos \theta}{2} \quad (2.13)$$




Figura 2.6: Función de apertura y cierre propuesta por Mayes y Davies

Capítulo 3

Redes Neuronales Artificiales (RNA)

3.1 Introducción a las Redes Neuronales Artificiales (RNA)

Las RNA son modelos que buscan imitar el funcionamiento del cerebro humano. El cerebro es capaz de tratar una gran cantidad de información procedente de los sentidos, combinar o comparar la información recibida con la información almacenada previamente y generar una respuesta adecuada, incluso en situaciones nuevas. Para ello, es necesario emplear la experiencia adquirida en situaciones pasadas. Para poder realizar todo esto, el cerebro humano está compuesto de decenas de billones de neuronas que se encuentran interconectadas entre sí, formando redes que realizan

funciones específicas. De esta forma, las neuronas reciben señales en forma de pulsos eléctricos de las que se encuentran conectadas a ella. Estas señales, se suman en el soma (núcleo de la neurona) y la señal resultante se propaga a través del axón. La señal resultante puede ser reforzada o debilitada, de manera que la señal que entra en una neurona puede no ser igual a la señal que salió de la neurona de origen. El contacto axón-dendrita se realiza mediante la sinapsis y tanto el axón como la dendrita, solo puede transmitir la señal en una dirección.




Figura 3.1: Partes de una neurona de un cerebro [4]

Por tanto, las RNA se encargan de establecer relaciones no lineales entre una serie de datos de entrada y proporcionar una serie de datos de salida, de manera que cuando se tengan nuevos valores de entrada se pueda estimar la salida. Para ello, es necesario que la RNA adquiera una experiencia mediante una etapa de aprendizaje, de manera que en esta etapa se ajustan los pesos w_{ji} (ver figura 3.2). Estos pesos multiplican los valores de entrada (x_i) que recibe la neurona, lo que determina la importancia de estas entradas. Las entradas ponderadas son sumadas en la neurona j y el valor obtenido entra en una función de activación que “activa más o menos” el valor que pasará a la siguiente neurona.

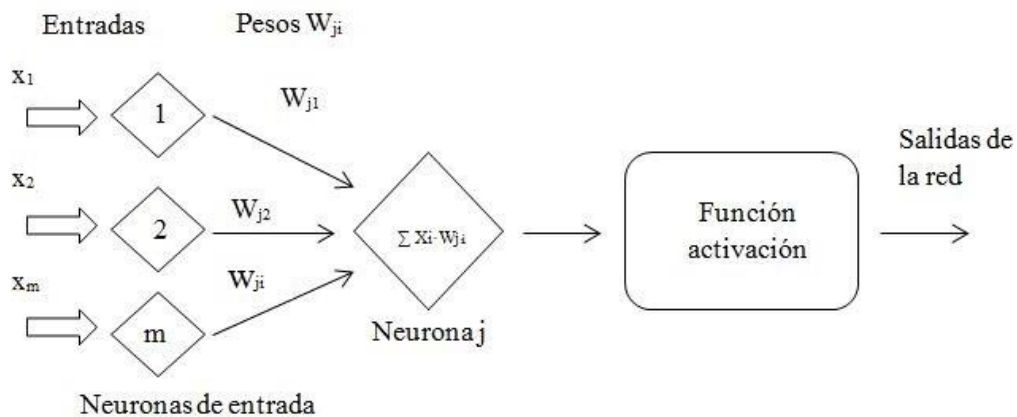


Figura 3.2: Propagación y ponderación de señales en una red neuronal

3.1.1 Etapas de una RNA

La modelización con redes neuronales implica dos etapas [4]:

- **Aprendizaje:** consiste en el entrenamiento de la red utilizando un conjunto de datos, llamados patrones de entrenamiento. Durante esta etapa, los patrones se ejecutan iterativamente, de manera que se van modificando los pesos, hasta que convergen a un conjunto de pesos óptimos que producen una respuesta satisfactoria. El conjunto de datos empleados en el entrenamiento tiene que contener un número mínimo de datos, si el conjunto de datos es reducido, los pesos no se adaptarán de forma eficaz y este conjunto de datos ha de ser representativo, todas las regiones del conjunto de datos tienen que estar lo suficientemente representadas. Hay tres tipos de aprendizaje:
 - Aprendizaje supervisado: Para cada valor de entrada de la red hay una salida deseada. La salida estimada por la red se compara con la salida deseada y la diferencia entre ambas determinará como se modificarán los pesos. Se busca minimizar las diferencias entre los valores de salida de la red y los valores deseados.




Figura 3.3: Esquema aprendizaje supervisado

- Aprendizaje no supervisado: No se especifica la salida deseada. La red emplea una regla de autoorganización.




Figura 3.4: Esquema aprendizaje no supervisado

- Aprendizaje reforzado: Se indica si la salida obtenida por la red es correcta o no, pero no especifica cuál es la salida que hay que obtener.

El conjunto de datos empleados para el entrenamiento se divide en dos conjuntos, uno de entrenamiento y otro de validación. El conjunto de entrenamiento se empleará para determinar los valores de los pesos y el conjunto de validación se utilizará para la medida del error en el conjunto de datos empleado en la etapa de entrenamiento. De esta manera, se utilizan datos no empleados en el entrenamiento para medir la eficacia de la red para resolver el problema y la capacidad de generalización de la red. Para que este proceso sea eficaz, no puede haber ningún tipo de sesgo en la selección del conjunto de datos de validación.

- **Generalización**: en esta etapa se aplica a la red ya entrenada, datos que no han sido utilizados en el entrenamiento.

3.2 Redes perceptron multicapa

Las redes perceptron multicapa son una generalización de la red perceptron simple, uno de las primeras redes neuronales artificiales, debido a las limitaciones que presentaba dicha arquitectura para problemas no lineales. De esta forma, las redes perceptron multicapa se definen como aproximadores universales siendo una de las arquitecturas más empleadas en la resolución de problemas.

La arquitectura de este tipo de redes está formada por varias capas de neuronas situadas en diferentes niveles, una capa de entrada, una o varias capas ocultas y una capa de salida.

Las neuronas situadas en la capa de entrada tienen la única función de recibir los valores de entrada a la red y propagar estas entradas a todas las neuronas de la siguiente capa. La última capa proporciona la salida de la red, proporcionando la respuesta de la red para cada uno de los valores de entrada. Las neuronas situadas en las capas ocultas realizan un tratamiento no lineal de los datos recibidos.




Figura 3.5: Arquitectura de una RNA perceptron multicapa

Las neuronas de las capas ocultas se encargan de procesar la información recibida empleando una función de activación. Esta función se encarga de calcular el estado de actividad de la neurona y convierte la entrada ponderada en un valor de activación. Estos valores de activación se encuentran generalmente entre los rangos $[0,1]$ y $[-1,1]$.

Las funciones de activación más utilizadas son [4]:

- Función sigmoidea o logística:

$$y_j = \frac{1}{1 + e^{-\alpha \sum x_i w_{ji}}}$$




Figura 3.6: Función sigmoidea o logística

- Función tangente hiperbólica:

$$y_j = \frac{e^{\alpha \sum x_i w_{ij}} - e^{-\alpha \sum x_i w_{ij}}}{e^{\alpha \sum x_i w_{ij}} + e^{-\alpha \sum x_i w_{ij}}}$$




Figura 3.7: Función tangente hiperbólica

- Función escalón:

$$y_j = \begin{cases} a, & \text{si } \sum x_i w_{ij} > 0 \\ -a, & \text{si } \sum x_i w_{ij} \leq 0 \end{cases}$$




Figura 3.8: Función escalón

Finalmente, la función de salida procesa el valor de activación obtenido. Generalmente la función de salida se corresponde con una función identidad aunque también puede aplicarse otro de tipo de funciones como la función escalón.

3.2.1 Algoritmo de retropropagación

El algoritmo de retropropagación es el mecanismo a través del cual se van adaptando los parámetros de la red. Este algoritmo consiste en dos fases [4]:

- En la primera fase hacia adelante, los pesos se mantienen fijos y se propagan de una capa a otra.
- En la segunda fase hacia atrás, los pesos son ajustados mediante la aplicación de una regla de corrección que se basa en la propagación hacia atrás del error cometido en los valores de salida de la red.

Este tipo de redes emplea un aprendizaje supervisado, buscando minimizar el error de las salidas en los patrones utilizados.

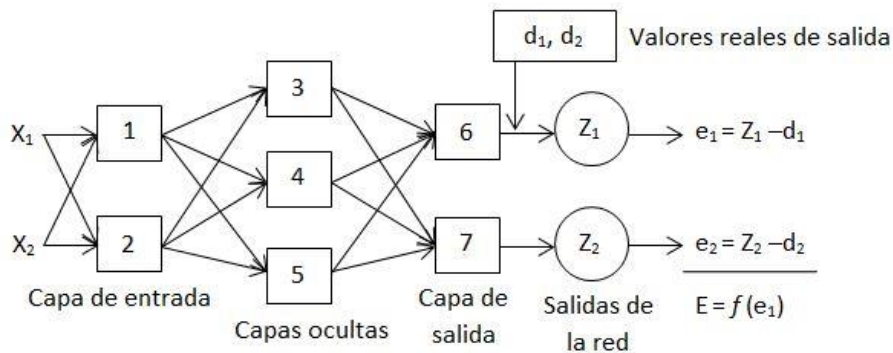


Figura 3.9: Esquema de funcionamiento del algoritmo de retropropagación

De esta manera, la red buscará que la salida de las que ofrece la red se encuentre lo más próxima posible a la salida deseable. La función E , es una función error que estima las diferencias entre ambas salidas. La propagación del error se realiza en la dirección negativa del gradiente de la función error. Esta función se define como [5]:

$$E = \frac{1}{N} \sum_{n=1}^N e(n) \quad (3.1)$$

donde N es el número de patrones y $e(n)$ es el error cometido por la red para el patrón n , expresado por:

$$e(n) = \frac{1}{2} \sum_{i=1} (z_i - d_i)^2 \quad (3.2)$$

siendo z_i los valores de salida de red y d_i los valores de salidas deseadas.

De esta forma, el aprendizaje de una red perceptron multicapa es equivalente a hallar un mínimo de la función error. Este aprendizaje debe buscar minimizar el error total y para ello el procedimiento más común es el método del gradiente estocástico, que consiste en una sucesiva minimización de los errores de cada patrón. De manera que aplicando este método cada parámetro w se modifica para cada patrón de entrada, a través de la siguiente ley de aprendizaje:

$$w_{ji} = w_{ji-1} + \Delta w_{ji} \quad (3.3)$$

De esta forma, la variación de los pesos en la neurona j depende de la derivada de la función de activación de la neurona y del error cometido en ella:

$$\Delta w_{ji(n)} = -\eta \frac{\delta e(n)}{\delta w_{ji}} = \eta \cdot e_{j(n)} \cdot \phi'_{j(n)} \cdot y_{ji} = \eta \cdot \delta_{j(n)} \cdot y_{ji} \quad (3.4)$$

donde e_j es el error para el patrón j , η es la razón de aprendizaje y δ es el gradiente local.

Puesto que el error de la neurona j de la capa de salida es conocido, se pueden obtener los pesos de esta capa:

$$w_{ki}^s = -\eta \frac{\delta e_n}{\delta w_{ki}^s} = -\eta \cdot e_{k(n)} \cdot \varphi'_{j(n)} \cdot y_{ki(n)} = \eta \cdot \delta_{k(n)} \cdot y_{ki(n)} \quad (3.5)$$

donde y_{ki} son los valores de salida de la neurona i que son los valores de entrada de la neurona k .

Para el cálculo del error en las neuronas ocultas se emplea el algoritmo de retropropagación a partir del error de las neuronas de la capa siguiente:

$$\Delta w_{ji(n)} = -\eta \cdot \varphi'_{j(n)} \sum_k (e_{k(n)} \varphi'_{k(n)} w_{kj(n)}) \cdot y_{ji(n)} = -\eta \cdot \varphi'_{j(n)} \sum_k (\delta_{k(n)} w_{kj(n)}) \cdot y_{ji(n)} \quad (3.6)$$

donde $\delta_{k(n)}$ es el gradiente local de las neuronas de la capa siguiente, conectadas con la neurona j que está siendo analizada.

La razón de aprendizaje es el parámetro que controla el cambio de los pesos en cada iteración. Si este parámetro es pequeño, converge lentamente, mientras que si la razón de aprendizaje es grande, la red convergerá de forma más rápida, pero puede producirse inestabilidad.

Para evitar la inestabilidad debido al incremento de la razón de aprendizaje alta, se introduce un segundo término, llamado momento (α) que tiene en cuenta la anterior iteración:

$$\Delta w_{ji(n)} = \alpha \cdot \Delta w_{ji(n-1)} + \eta \cdot \delta_{j(n)} \cdot y_{ji(n)} = \eta \cdot \sum_{n=0}^t \alpha_{(t-n)} \cdot \delta_{j(n)} \cdot y_{ji(n)} \quad (3.7)$$

De forma que la inclusión de este nuevo término provoca un cambio más suave en la variación de los pesos conduciendo a un método más estable sin oscilaciones bruscas.

3.3 Redes Neuronales de base radial

Las redes neuronales de base radial son redes definidas como aproximadores universales. Estas redes son redes multicapa con conexiones hacia adelante. La arquitectura de este tipo de red está formada por tres capas de neuronas: una capa de entrada, una capa oculta y una capa de salida. En la figura 3.10 se muestra un esquema de la arquitectura de este tipo de redes.




Figura 3.10: Arquitectura de una red de base radial

La capa de entrada se encarga de recibir los valores de entrada sin procesar estos valores. En la capa oculta, se reciben los valores procedentes de la capa de entrada y se procesan estos valores. En la capa de salida se combinan linealmente la activaciones de la capa oculta y proporciona los valores de salida de la red. Las conexiones entre la capa de entrada y la capa oculta no llevan asociado ningún peso mientras que las conexiones entre la capa oculta y la capa de salida sí que llevan asociado un peso.

Las activaciones de las neuronas de salida vienen dadas por la siguiente expresión [5]:

$$y_k(n) = \sum_{i=1}^m w_{ik} \phi_i(n) + u_k \quad \text{para } k = 1, 2, \dots, r \quad (3.8)$$

donde m son las neuronas de la capa oculta, r las neuronas de la capa de salida, w_{ik} es el peso de la conexión de la neurona oculta i a la neurona de salida k , u_k es el umbral de la neurona de salida k y $\phi_i(n)$ son las activaciones de las neuronas ocultas.

Estas activaciones de las neuronas ocultas $\phi_i(n)$ o también llamadas funciones de base radial determinan el valor de activación de las neuronas de la capa oculta de la red y vienen expresadas por [5]:

$$\phi_i(n) = \phi\left(\frac{\|X(n) - C_i\|}{d_i}\right) \quad \text{para } i = 1, 2, \dots, m \quad (3.9)$$

donde C_i es un vector que representa los centros de la función de base radial, d_i son números reales que indican la desviación de la función de base radial y $\|X(n) - C_i\|$ representa la distancia del vector de entrada $X(n)$ al centro C_i y se define como:

$$\|X(n) - C_i\| = \left(\sum_{j=1}^p (x_j(n) - c_{ij})^2 \right)^{\frac{1}{2}} \quad (3.10)$$

En las redes neuronales de base radial, la función radial más utilizada es la función gaussiana que se expresa como:

$$\phi(r) = e^{\left(\frac{-r^2}{2}\right)} \rightarrow \phi(n) = \exp \frac{-\sum_{j=1}^p (x_j(n) - c_{ij})^2}{2d_i^2} \quad (3.11)$$




Figura 3.11: Función gaussiana

El aprendizaje de este tipo de redes implica la determinación de los parámetros de la red. De manera que durante la etapa de aprendizaje se procederá al cálculo de los centros y las desviaciones de las neuronas de la capa oculta, los pesos de las conexiones entre la capa oculta a la capa de salida y los umbrales de las neuronas de salida.

Hay dos métodos de aprendizaje para este tipo de redes [5]:

- Método de aprendizaje híbrido: Este método es el más empleado y consta de dos fases:
 - Fase no supervisada: en esta fase se determinan los centros y amplitudes de las neuronas de la capa oculta.
 - Fase supervisada: cálculo de los pesos y umbrales de la capa de salida.
- Método de aprendizaje totalmente supervisado: En este caso los parámetros de la red se calculan de manera que el error cuadrático medio sea el mínimo posible, es decir, que la diferencia entre los valores de salida estimados por la red y los valores esperados sean mínimos.

Capítulo 4

Metodología

4.1 Planteamiento del problema

Se considera un eje de longitud $L = 900$ mm y diámetro $D = 20$ mm, que contiene una fisura de profundidad a en su sección central. El eje está formado de aluminio con un módulo de elasticidad $E = 72$ GPa, densidad $\rho = 2800$ kg/m³ y coeficiente de Poisson $\nu = 0.33$. El eje está apoyado en sus extremos y se encuentra sometido a dos cargas puntuales $F = 100$ N, aplicadas a una distancia d de los extremos del eje, de forma que la sección que contiene la fisura está sometida a un estado de flexión pura. En la figura 4.1 se muestra el problema propuesto.




Figura 4.1: Esquema del eje fisurado [1]

Para la resolución del problema se han considerado los siguientes valores de los parámetros:

- Factor de forma de la fisura (β): Se consideran cinco valores de β , de 0 a 1 en intervalos de 0.25.
- Profundidad relativa de la fisura (α): Para α se emplean seis valores diferentes, $\alpha = 0.1, 0.2, 0.25, 0.3, 0.4$ y 0.5 .

En la figura 4.2 se pueden observar de manera gráfica los distintos valores considerados de β y α :

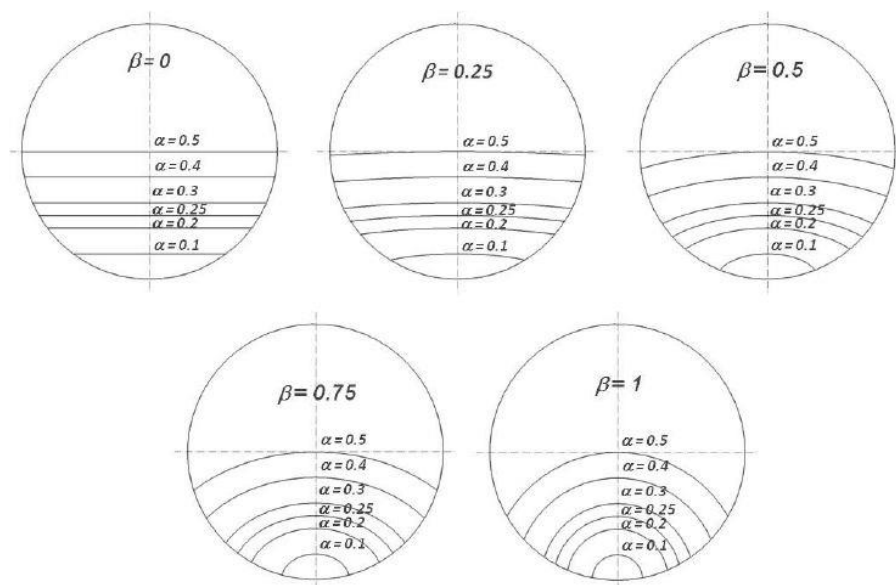


Figura 4.2: Variación de la profundidad relativa y del factor de forma de la fisura [1]

- Posición relativa del frente de fisura (γ): Se consideran valores de γ desde -0.83 a 0.83 en intervalos de 0.16. En la figura 4.3 se muestran los valores considerados para la posición relativa del frente de fisura:




Figura 4.3: Posiciones en el frente de la fisura [1]

- Angulo de giro del eje (θ): Se toman valores desde 0 a 2π radianes, en intervalos de $\frac{2\pi}{72}$ radianes.

Para la resolución del problema, se empleará el método directo. Con este método se procederá al cálculo del FIT a partir de los parámetros geométricos de la fisura. De esta manera, los valores de entrada de la RNA serán estos parámetros y la salida obtenida por la red será el FIT.

De esta manera, a partir de los resultados del FIT obtenidos bajo estas condiciones en la Tesis doctoral de Patricia Rubio Herrero [1] mediante el Método de los Elementos Finitos, se desarrollará una red neuronal para estimar el FIT en un giro completo del eje.

4.2 Programación de la Red Neuronal Artificial

El objetivo de este trabajo es la determinación del Factor de Intensidad de Tensiones, empleando el método de directo, mediante el uso de Redes Neuronales Artificiales.

Como se ha explicado en capítulos anteriores, hay distintos tipos de redes según su aprendizaje, su arquitectura, etc. Para abordar este problema, se ha empleado una red perceptron multicapa con algoritmo de retropropagación, con un aprendizaje supervisado, dado que se le proporcionará la salida deseada a la red. Los valores de entrada de la red serán los parámetros geométricos (α , β y γ) y la posición angular de la fisura (θ) y los valores de salida de la red será el FIT adimensional.

Para el desarrollo de la red neuronal se han seguido los siguientes pasos:

1. Adecuación de los datos empleados por la red: Primero hay que crear un archivo que contenga los datos que posteriormente serán introducidos en la red neuronal. Dado que el aprendizaje que utilizará la red será supervisado, este archivo contendrá los datos tanto de entrada como de salida.

Como datos de entrada a la red se tomarán la profundidad relativa de fisura (α), el factor de forma de la fisura (β), la posición relativa en el frente de fisura (γ) y la posición angular de la fisura (θ) y como dato de salida de la red el FIT adimensional.

Las redes que emplean un algoritmo de retropropagación realizan un test de validación durante el aprendizaje para el cálculo del error cometido en los valores de salida estimados y su propagación hacia atrás en la red. Una vez obtenida la red ya entrenada, se realiza la generalización con datos no empleados en el aprendizaje. Por tanto, los datos han de dividirse, siendo destinados un 60% al aprendizaje, un 20% para el test de validación y un 20% para la generalización [6].

Para este proyecto, se parte de 20075 datos de cada uno de los cinco parámetros. Estos datos se dividen en dos archivos, uno que incluye los datos empleados en aprendizaje y en el test de validación y otro archivo que incluye los datos utilizados en la generalización. El primer archivo contendrá 16060 datos, de los que 12045 se

utilizarán para el entrenamiento y 4015 datos se emplearán para el test de validación. El otro archivo se empleará para la generalización y tendrá un total de 4015 datos. La separación de datos se ha de realizar al azar, para intentar que estos datos sean lo más representativos posible.

Una vez que los datos han sido preparados, hay que indicar en el código empleado para la red que datos se corresponden con las entradas y cuales con las salidas.

2. Diseño de la estructura empleada para la red: A partir del código base de una red neuronal perceptron multicapa con algoritmo de retropropagación se procede a la realización de la red neuronal. Esta red constará de cuatro capas ocultas de neuronas, con una función de activación sigmoidea o logística. En este código se indicará el tamaño del set de validación que se empleará durante el entrenamiento. Para obtener unos valores de salida de la red óptimos, estos parámetros han de ser modificados hasta encontrar el resultado deseado.

Una vez ejecutada la red empleando el software *Matlab*, este programa nos ofrece dos gráficas, una en la que se muestran los datos reales empleados en el entrenamiento y los valores de salida estimados por la red y otra en la que se muestran los valores de generalización.




Figura 4.4: Ejemplo de gráfica de representación de datos reales y estimados por la red para el entrenamiento

Además de la representación gráfica, *Matlab* también nos ofrece la posibilidad de calcular el error cuadrático medio (MSE) producido entre los valores reales y los estimados por la red. La expresión para el cálculo del error cuadrático medio será la siguiente:

$$MSE = \frac{\sum_{i=1}^n (est_i - real_i)^2}{n} \quad (4.1)$$

donde *est* es el valor estimado por la red y *real* hace referencia a los valores reales.

De esta manera, *Matlab* permite la posibilidad de obtener una representación de la evolución del error cuadrático medio en cada iteración.




Figura 4.5: Representación de la evolución del MSE

Otra forma de evaluar si la red es correcta es empleando una recta de regresión lineal. *Matlab* nos ofrece la posibilidad de mostrarnos los resultados empleando una recta de regresión lineal y el valor de *R*, que será el coeficiente de correlación. Este coeficiente es una medida de la relación lineal entre la salida introducida en la red y la salida de la red, de forma que si este coeficiente es 1 la correlación será positiva perfecta mientras que si es 0 no existirá relación lineal entre las variables.

De manera que *Matlab* nos proporcionará las rectas de regresión lineal para los datos empleados en el entrenamiento y los datos empleados en la validación con sus respectivos valores obtenidos del factor de correlación R .




Figura 4.6: Ejemplo de recta de regresión lineal proporcionada por Matlab

3. Obtención de la red entrenada: Tras realizar el diseño de la red para obtener unos resultados óptimos, se obtiene una red que está entrenada correctamente.

De esta forma, esta red se podrá utilizar para estimar datos de salida. A partir de unos valores de entrada, que en nuestro caso serán los parámetros geométricos característicos α , β , γ y θ , la red será capaz de estimar valores de salida, que en nuestro caso será el valor del FIT adimensional.




Figura 4.7: Ejemplo de gráfica de representación de datos reales y estimados por la red para la generalización

Capítulo 5

Resultados y discusión

5.1 Resultados

Mediante el uso de *MatLab* se han estimado los valores del FIT adimensional mediante el uso de Redes Neuronales Artificiales (RNA) para un eje rotatorio que contiene una fisura.

De esta manera, se ha resuelto el problema directo, es decir, a partir de los parámetros característicos de una fisura y la posición angular de la misma se han obtenido valores estimados del FIT adimensional.

En la figura 5.1 se muestran los valores de los datos reales y los datos de salida que han sido estimados por la red durante la etapa de aprendizaje:




Figura 5.1: Gráfica obtenida durante la etapa de aprendizaje

A parte de la obtención gráfica de resultados, también se obtiene el error cuadrático medio para el entrenamiento y para la generalización. El MSE obtenido por la red desarrollada para el entrenamiento es de $1.28 \cdot 10^{-4}$ y el MSE obtenido para la generalización $1.74 \cdot 10^{-4}$.

Otra forma de analizar los resultados, es mediante el uso de una recta de regresión lineal. *MatLab* nos proporciona la recta de regresión lineal para los datos obtenidos tras el entrenamiento y la validación. Además de proporcionarnos estas rectas gráficamente, también nos proporciona el valor del coeficiente de correlación R . Las rectas de regresión obtenidas son las siguientes:




Figura 5.2: Recta de regresión lineal obtenida para el entrenamiento




Figura 5.3: Recta de regresión lineal obtenida para la validación

De manera que se obtiene un valor para el coeficiente de correlación de 0.99949 para los valores empleados en el entrenamiento y un valor de 0.99929 para los datos empleados en la validación.

Con el fin de validar la red, se han realizado diversas gráficas comparativas para diversos valores de la profundidad relativa de la fisura, el factor de forma de la fisura y de la posición relativa del frente de fisura. De esta forma se pretende demostrar que la red neuronal es válida y puede aplicarse de manera correcta para cualquier valor de los parámetros de entrada de la red. A continuación, se muestran las gráficas realizadas:




Figura 5.4: Comparación de los valores del FIT adimensional estimado por la red neuronal frente a los valores introducidos en la red neuronal para $\beta = 0$ y $\alpha = 0.1$




Figura 5.5: Comparación de los valores del FIT adimensional estimado por la red neuronal frente a los valores introducidos en la red neuronal para $\beta = 0$ y $\alpha = 0.3$




Figura 5.6: Comparación de los valores del FIT adimensional estimado por la red neuronal frente a los valores introducidos en la red neuronal para $\beta = 0$ y $\alpha = 0.5$




Figura 5.7: Comparación de los valores del FIT adimensional estimado por la red neuronal frente a los valores introducidos en la red neuronal para $\beta = 0.5$ y $\alpha = 0.1$




Figura 5.8: Comparación de los valores del FIT adimensional estimado por la red neuronal frente a los valores introducidos en la red neuronal para $\beta = 0.5$ y $\alpha = 0.3$




Figura 5.9: Comparación de los valores del FIT adimensional estimado por la red neuronal frente a los valores introducidos en la red neuronal para $\beta = 0.5$ y $\alpha = 0.5$




Figura 5.10: Comparación de los valores del FIT adimensional estimado por la red neuronal frente a los valores introducidos en la red neuronal para $\beta = 1$ y $\alpha = 0.1$




Figura 5.11: Comparación de los valores del FIT adimensional estimado por la red neuronal frente a los valores introducidos en la red neuronal para $\beta = 1$ y $\alpha = 0.3$




Figura 5.12: Comparación de los valores del FIT adimensional estimado por la red neuronal frente a los valores introducidos en la red neuronal para $\beta = 1$ y $\alpha = 0.5$

5.2 Discusión de los resultados

A la vista de los resultados obtenidos en el apartado anterior se puede concluir que se puede estimar el valor del Factor de Intensidad de Tensiones adimensional a partir de los valores de los parámetros geométricos de la posición en el frente de una fisura y de la posición angular en que se encuentra la fisura empleando una red neuronal artificial.

El error cuadrático medio (MSE) obtenido tanto para la etapa de aprendizaje como para la etapa de generalización es pequeño, del orden de 10^{-4} . Esto nos indica que el error cometido entre el valor estimado y el valor real es asumible y la estimación realizada es bastante precisa.

Respecto al factor de correlación R , se obtienen valores muy próximos a 1, tanto para el aprendizaje como para el set de validación. Esto nos indica que existe una correlación positiva perfecta entre los valores de salida introducidos en la red y los valores de salida estimada por la red. Por tanto, entre las salidas obtenidas y las reales existe una relación directa y la estimación realizada se ajusta a los valores objetivo.

Para refrendar que la red diseñada es correcta, en el apartado 5.1 se muestran diversas gráficas con el objetivo de demostrar que la red funciona de manera correcta independientemente de los datos para los que se realiza la estimación. Para ello, se han tomado diferentes valores de los parámetros geométricos (α , β y γ) y se ha realizado una gráfica comparativa entre el valor real y el valor estimado por la red del FIT adimensional a lo largo de un giro completo. En estas gráficas se observa que independientemente de los valores de entrada introducidos en la red neuronal, esta funciona correctamente y es capaz de realizar una estimación precisa para cualquier valor de las variables de entrada. También se puede observar que los puntos donde la estimación obtenida por la red es menos precisa, se encuentran en las zonas de transición entre fisura parcialmente abierta y fisura cerrada, no obstante, el error cuadrático máximo detectado en esas zonas es de $8 \cdot 10^{-4}$. Teniendo en cuenta que el error cuadrático medio obtenido en la etapa de generalización es de $1.74 \cdot 10^{-4}$, este error máximo obtenido es aceptable.

Capítulo 6

Conclusiones y trabajos futuros

6.1 Conclusiones

Tras la realización de este presente Trabajo Fin de Grado se puede afirmar que se ha conseguido cumplir el objetivo inicial: diseñar una red neuronal capaz de determinar de manera correcta los valores del FIT adimensional a lo largo de un giro completo.

Para conseguir el objetivo propuesto, se ha empleado una red perceptron multicapa con algoritmo de retropropagación que ha permitido la resolución del

problema directo. Tras los resultados mostrados en el capítulo 5, ha quedado demostrado que se puede aplicar una red neuronal para la resolución del problema propuesto, obteniendo un MSE bajo, un valor cercano a 1 para el factor de correlación y demostrando que los valores empleados para las variables de entrada no influyen en el correcto funcionamiento de la red.

Por tanto, se puede concluir que se puede emplear una red neuronal para realizar un estudio del FIT en un eje giratorio a lo largo de un giro completo.

6.2 Trabajo futuros

Tras los resultados obtenidos en este trabajo se pueden proponer como trabajos futuros:

- Realizar un estudio para la aplicación de redes neuronales para la resolución del problema inverso para un eje giratorio a lo largo de un giro completo.
- Realizar medidas experimentales en un eje real, de manera que se puedan comparar tanto los datos empleados para realizar la red neuronal, que fueron obtenidos mediante el Método de los Elementos Finitos y los datos estimados aplicando la red neuronal.

Capítulo 7

Presupuesto

7.1 Planificación

A continuación se presenta la planificación que se ha seguido para la realización de este Trabajo Fin de Grado. El trabajo se ha desarrollado a lo largo de 5 meses y se ha dividido en las siguientes fases:

- 1. Planteamiento del trabajo (23/2/2015):** La primera fase es realizar una reunión con la tutora de este Trabajo Fin de Grado para explicar en que se basa el trabajo a realizar y las herramientas a emplear.

2. **Inicio del trabajo (2/3/2015):** Se realiza una segunda reunión en la que se profundiza con más detalle sobre el tema del trabajo propuesto. Se proporciona material, tanto teórico como práctico, para el inicio del proyecto.
3. **Planificación del trabajo (4/3/2015):** En esta fase se divide el trabajo en partes y se programa el orden en que se realizarán estas tareas.
4. **Aprendizaje programación RNA (5/3/2015-2/4/2015):** Inicialmente se recurre a la realización de ejercicios sencillos y a la lectura de un manual para aprender a programar Redes Neuronales Artificiales empleando *MatLab*.
5. **Desarrollo RNA (6/4/2015-12/5/2015):** En esta fase se procede a aplicar los conocimientos adquiridos para la programación de RNA desarrollando diversas redes con objeto de encontrar una red cuyo comportamiento sea lo más correcto posible.
6. **Redacción de la memoria (22/4/2015-12/6/2015):** Por último, se procede a la redacción de la presente memoria. En esta parte se incluye tanto la redacción del texto como la obtención de las imágenes empleadas en el trabajo.

A continuación se muestra un diagrama de Gantt de las tareas que se han realizado:




Figura 6.1: Diagrama de Gantt

En la figura 6.1 se muestra el diagrama de Gantt del Trabajo Fin de Grado, en el que se puede observar el orden de las tareas, su localización temporal y la duración de las mismas.

7.2 Presupuesto

En este apartado se presenta un análisis de los costes económicos de este trabajo. A continuación se detallan los costes debido a personal, equipos y software empleados para la elaboración del Trabajo Fin de Grado:

PERSONAL			
Descripción	Dedicación (horas)	Coste horario (€/h)	Coste (€)
Aprendizaje y desarrollo RNA	118	30	3.540
Redacción memoria	55	30	1.650
Seguimiento del proyecto	20	80	1.600
SUBTOTAL			6.790

Tabla 1: Costes de personal

EQUIPOS					
Descripción	Coste total (€)	Utilización (%)	Dedicación (meses)	Periodo de depreciación (meses)	Coste (€)
Ordenador	800	100	4	66	48,5
SUBTOTAL					48,5

Tabla 2: Costes de equipos

SOFTWARE					
Descripción	Coste total (€)	Utilización (%)	Dedicación (meses)	Periodo de depreciación (meses)	Coste (€)
MatLab R2011a	8.000	100	4	42	761,9
Microsoft Office 2010	500	100	3	54	27,77
Microsoft Project 2013	1.300	100	1	30	43,33
SUBTOTAL					833

Tabla 3: Costes de licencias software

Para el cálculo de los costes de equipos y de licencias de software, se ha de tener en cuenta la siguiente expresión:

$$C = \frac{t}{T} \cdot P \cdot D \quad (6.1)$$

donde:

t es el número de meses que se ha empleado el software o equipo.

T es el periodo de depreciación.

P es el precio de compra del software o equipo.

D es la utilización del equipo en porcentaje.

A estos costes hay que añadir los costes indirectos, que son un 15% del total del coste de personal, equipos y software. De forma que los costes totales serán:

COSTES TOTALES	
Concepto	Coste (€)
Personal	6.790
Equipos	48,5
Software	833
Costes Indirectos	1.150,73
TOTAL	8.822,23

Tabla 4: Costes totales

De esta manera, el coste total del proyecto será de 8.822,23€.

Bibliografía

[1] Patricia Rubio Herrero “Factor de Intensidad de Tensiones en fisuras elípticas con mecanismo de apertura y cierre en ejes giratorios”. Tesis Doctoral, Universidad Carlos III de Madrid, Febrero de 2014.

[2] L. Rubio, B. Muñoz “Determinación de la flexibilidad de ejes con fisuras de frente elíptico”. *Anales de mecánica de la fractura*, Vol.2 , pp. 587-592, 2007.

[3] Alexandra Feito Redruello “Identificación de fisuras semielípticas en ejes sometidos a solicitaciones combinadas de flexión tracción mediante la aplicación de Redes Neuronales”. Proyecto de fin de carrera, Ingeniería Técnica Industrial, especialidad Mecánica, Universidad Carlos III de Madrid, Octubre de 2011.

[4] Isabel González Farias “Redes Neuronales Artificiales”. Transparencias de la asignatura de Técnicas Avanzadas de Diseño en Ingeniería Mecánica, impartida en el Máster en Ingeniería de Máquinas y Transporte de la Universidad Carlos III. 2008.

[5] P. Isasi Viñuela, I. M. Galván León “Redes de neuronas artificiales. Un enfoque práctico”. Pearson Educación, S.A., Madrid, 2004.

- [6] Howard Demuth, Mark Beale, Martin Hagan “Neural Network’s Toolbox User’s guide”. The MathWorks Inc, 2005.
- [7] B. Muñoz-Abella, L. Rubio “Detección e identificación de fisuras de frente semielíptico en ejes mediante la aplicación de algoritmos genéticos”. XVIII Congreso Nacional de Ingeniería Mecánica. España. 2010.
- [8] I. Mayes, W. Davies “Analysis of the response of a multi-rotor-bearing system containing a transverse crack in a rotor”. Journal of Vibration, Acoustics, Stress, and Reability in Design 106 (1984) 139–145.

